

## ANÁLISE TEXTURAL E CLASSIFICAÇÃO DIGITAL DE IMAGENS SAR PARA DISCRIMINAÇÃO DE ALVOS AGRÍCOLAS

TEXTURE ANALYSIS AND DIGITAL CLASSIFICATION OF SAR IMAGES FOR  
AGRICULTURAL TARGET DISCRIMINATION

**Silvio Pimentel MARTINS**

Instituto Brasileiro de Geografia e Estatística (IBGE). Rua Coronel Peixoto, 17. Centro. Cuiabá – MT.  
E-mail: pmartins.silvio@gmail.com

Introdução  
Área de estudo  
Materiais e métodos  
Correção geométricas das imagens  
Interpretação visual das imagens ETM+, F5A, S7D e definição das classes de estudo  
Medidas de textura  
Classificação digital das imagens  
Resultados e discussão  
Interpretação da imagem ETM+ e análise visual das imagens F5A e S7D  
Definição das classes de estudo e coleta de amostras de treinamento e teste  
Seleção das medidas de textura com maior potencial de discriminação  
Classificação das imagens F5A e S7D  
Imagem F5A  
Imagem S7D  
Conclusões  
Referências

**RESUMO** - As imagens de sensoriamento remoto da faixa do visível e infravermelho do espectro eletromagnético apresentam grande potencial na discriminação de áreas agrícolas para fins de estimativa de safra. Contudo, a presença de nuvens impede a aquisição deste tipo de imagens, porém, as imagens SAR independem de condições meteorológicas. Neste contexto, este trabalho verificou o potencial de duas imagens SAR/Radarsat-1, banda C, polarização HH, nos modos Fine-5/ascendente (F5A) e Standard-7/descendente (S7D) na discriminação de alvos agrícolas na região de Assis-SP. Os métodos se basearam em análises visuais e na comparação das classificações digitais das imagens F5A e S7D originais, filtradas e medidas de textura destas. Os resultados indicaram que as imagens filtradas melhoraram a discriminação dos alvos em relação às imagens originais, sendo o filtro adaptativo *Gamma*, o mais eficiente entre os outros filtros testados. As classificações das imagens de textura foram, em geral, melhores do que as classificações das imagens filtradas, indicando que as medidas de textura podem ser atributos úteis para maximizar a discriminação de alvos agrícolas. As classes com maior potencial de discriminação em ambas as imagens F5A e S7D, com exatidão acima de 50%, foram: água, área urbana, cana-de-açúcar-2, soja e solo exposto-1.

**Palavras-chave:** Radarsat-1. Máxima Verossimilhança (MAXVER). Filtros adaptativos. Sensoriamento remoto. Alvos agrícolas.

**ABSTRACT** - The remote sensing images of the visible and infrared range of the electromagnetic spectrum have great potential for discriminating agricultural areas for the purpose of estimating the yield. Nevertheless, the presence of clouds prevents the acquisition of this type of images, however, the SAR images are independent of meteorological conditions. In this context, this work verified the potential of two SAR/Radarsat-1 images, C band, HH polarization, in Fine-5/ascending (F5A) and Standard-7/descending (S7D) modes in the discrimination of agricultural targets in the region of Assis-SP. The methods were based on visual analyzes and on the comparison of the digital classifications of the original and filtered F5A and S7D images, as well as their texture measurements. The results indicated that the filtered images improved the discrimination of the targets in relation to the original images, with the *Gamma* adaptive filter being the most efficient among the other tested filters. Texture image classifications were generally better than filtered image classifications, indicating that texture measures can be useful attributes to maximize discrimination of agricultural targets. The classes with the greatest discrimination potential in both F5A and S7D images, with accuracy above 50%, were: water, urban area, sugarcane-2, soy and exposed soil-1.

**Keywords:** Radarsat-1. Maximum Likelihood (MAXVER). Adaptive filters. Remote sensing. Agricultural targets.

### INTRODUÇÃO

As imagens de sensoriamento remoto aliadas às técnicas de processamento digital de imagens apresentam potencial na discriminação e mapeamento rápido e confiável de culturas agrícolas para fins de estimativa de área e produtividade. Considerando a grande dimensão do território brasileiro e a intensa atividade agrícola em grande parte do país, o uso de imagens de sensoriamento

remoto tem sido uma opção viável para a obtenção de informações agrícolas devido à visão sinóptica dos sensores e repetição proporcionada pelos sistemas de imageamento a bordo de satélites.

Porém, as imagens de sensoriamento remoto óptico adquiridas nas faixas espectrais do visível e infravermelho do espectro eletromagnético apresentam limitações, em especial na agricultura,

por causa da intensa cobertura de nuvens por ocasião do crescimento e desenvolvimento das culturas agrícolas, dificultando a obtenção de imagens nesta faixa do espectro eletromagnético (Brisco & Brown, 1995; Ippoliti-Ramilo et al., 1999).

Já os sensores que operam na faixa espectral de microondas, os radares imageadores de abertura sintética (*Synthetic Aperture Radar* – SAR), adquirem imagens praticamente sem interferência das condições meteorológicas (Smith et al., 1995).

Além disso, por se tratar de um sistema ativo, que tem sua própria fonte de radiação, os radares independem da radiação solar para o imageamento podendo ser empregado tanto no período diurno quanto no noturno. Enquanto as imagens de sensores ópticos estão relacionadas às características físico-químicas dos alvos, as imagens de sensores de microondas estão relacionadas às propriedades dielétricas e geométricas dos alvos, trazendo, portanto, perspectivas promissoras em várias aplicações agrícolas (Brisco & Brown, 1997).

Porém, um dos maiores problemas na interpretação de imagens SAR é a presença do ruído *speckle* (Lewis & Henderson, 1997), que prejudica os aspectos radiométricos e texturais da imagem, dificultando a discriminação dos alvos. As imagens SAR são geralmente processadas de forma a reduzir esse tipo de ruído característico através do processamento *multilook* ou multivisada. A utilização de filtros em imagens já processadas, como os filtros convolucionais simples (média e mediana, por exemplo) e os pontuais adaptativos, minimizam o efeito do ruído *speckle* sem comprometer a resolução espacial, resultando na melhora da discriminação entre diferentes tipos de alvos tanto para os classificadores digitais por pixel como para os classificadores texturais (Lopes et al., 1990).

Os filtros adaptativos são os mais apropriados, pois estes preservam as informações radiométricas e de textura da imagem mais eficientemente. Os filtros adaptativos *Frost*, *Lee*, *Sigma*, *Kuan* e *Gamma* são os mais utilizados (Mather, 1999).

Entre as diversas técnicas de processamento digital de imagens de radar, destaca-se a classi-

ficação digital supervisionada. O classificador por Máxima Verossimilhança ou MAXVER com o algoritmo *Iterated Conditional Modes* - ICM foi desenvolvido especificamente para a análise e classificação de imagens SAR (Frery, 1993; Vieira, 1996). Diferentemente do MAXVER, em que cada pixel é classificado independentemente dos pixels vizinhos, o MAXVER/ICM leva em conta a informação contextual ou a influência das classes vizinhas.

O desempenho da classificação digital em imagens SAR monoespectrais pode ser melhorado com a utilização da informação textural da imagem, que se refere à variação espacial dos níveis de cinza vizinhos de um determinado alvo na imagem (Haralick et al., 1973; Mather, 1999). Em interpretação de imagens de radar, o atributo textural apresenta maior eficácia do que o atributo tonal (Ulaby et al., 1986a).

Vários estudos mostram que a utilização de técnicas de análises texturais em imagens SAR têm melhorado a classificação de alvos terrestres (Rennó, 1995; Soares et al., 1997; Morais et al., 1999; Presutti et al., 2001; Silva Junior, 2002; Soler, 2002).

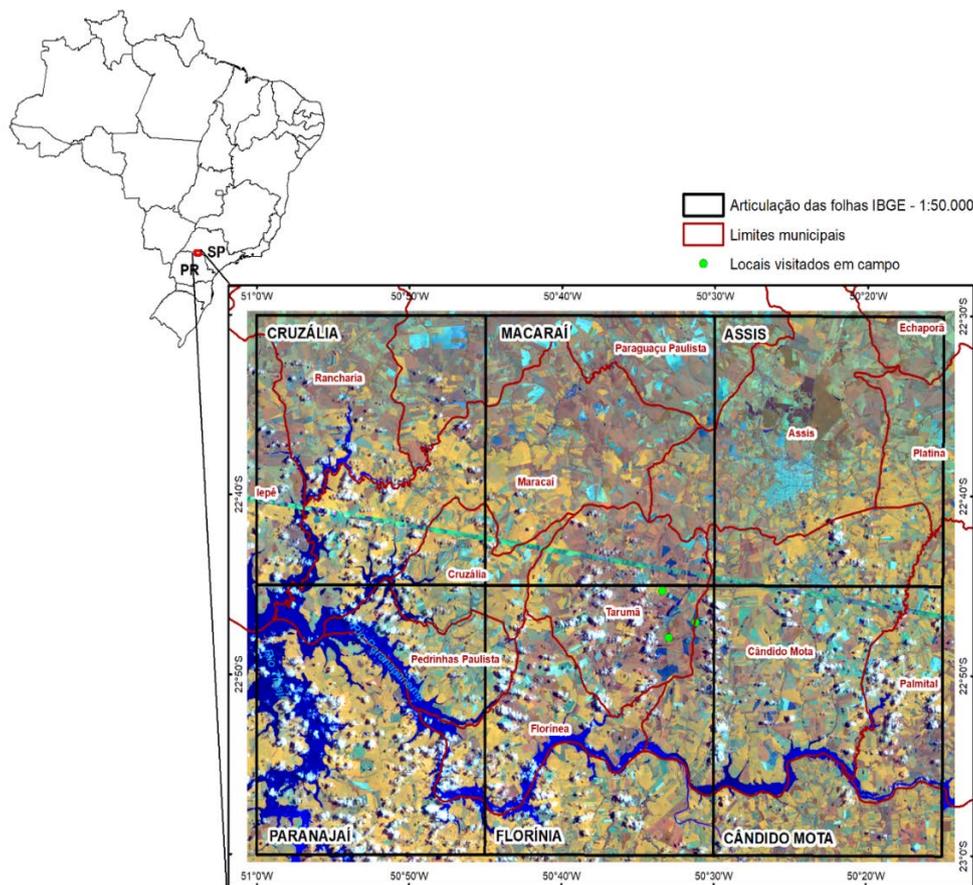
McNairn et al. (2002) avaliaram os resultados de classificações realizadas em imagens SAR/Radarsat-1 adquiridas ao longo da estação de crescimento de culturas agrícolas e observaram que as melhores classificações eram obtidas quando as culturas se encontravam na fase de máximo desenvolvimento. Nesse sentido, o presente trabalho tem por objetivo principal verificar o potencial de duas imagens SAR/Radarsat-1 (modos *Fine-5/Ascendente* e *Standard-7/Descendente*) na discriminação de culturas agrícolas na fase de máximo desenvolvimento na região de Assis, São Paulo.

As datas das imagens correspondem à fase de máximo desenvolvimento da cultura de soja e algumas variedades da cana-de-açúcar. A metodologia empregada se baseou na análise visual das imagens, na utilização de filtros adaptativos e atributos de textura visando avaliar o potencial destes de maximizar a discriminação dos alvos agrícolas nas classificações digitais.

## ÁREA DE ESTUDO

A área de estudo localiza-se na região do Médio Vale do Paranapanema, pertencente à região de Assis, São Paulo, cujo uso do solo se destina predominantemente à atividade agrícola (Figura 1). A região de Assis tem altitude de 500 m a oeste, a

qual diminui gradativamente para a bacia do Paraná, onde as cotas altimétricas atingem 300 m. O relevo é fortemente suavemente ondulado e o clima é do tipo tropical/subtropical (Aw) na classificação de Köppen (Tropmair, 2000).



**Figura 1** - Representação da região da área de estudo sobre a imagem do sensor ETM+/Landsat-7 na composição falsa cor RGB 453.

## MATERIAIS E MÉTODOS

Para o processamento e análise de imagens de radar, bandas de textura derivadas destas e classificações digitais, os dados utilizados foram duas imagens do sistema SAR/Radarsat-1 e uma imagem do sistema ETM+/Landsat-7 (ETM+), órbita/ponto 222/76. Para satisfazer os objetivos do trabalho, as imagens foram adquiridas no mês de fevereiro de 2003 durante a fase de pleno desenvolvimento vegetativo da cultura de soja.

A imagem ETM+ datada de 23 de fevereiro de 2003 foi utilizada como dado de referência. As imagens SAR/Radarsat-1, banda C e polarização HH utilizadas neste trabalho foram as dos modos *Fine-5/Ascendente (F5A)* e *Standard-7/Descen-*

*dente (S7D)*, nível de processamento SGF (*ground range*). A tabela 1 apresenta suas principais características.

O software ENVI 3.6 foi utilizado nos procedimentos de coleta das amostras de treinamento e teste, bem como para avaliar as classificações digitais. Os aplicativos Texture, ICM e Filter texture 3.0 foram desenvolvidos pelo Instituto Nacional de Pesquisas Espaciais – INPE e utilizados para gerar medidas de textura, classificação digital das imagens SAR e geração das imagens de textura, respectivamente. Os procedimentos metodológicos são descritos abaixo.

**Tabela 1** - Características das imagens utilizadas no trabalho.

Modo	F5A <sup>1</sup>	S7D <sup>1</sup>	ETM+
Data	14/02/2003	23/02/2003	23/02/2003
Ângulo de incidência	45°-47,8°	44,7°-49,2°	-
Número de <i>looks</i>	1 x 1 m	1 x 4 m	-
Horário de passagem	18:04 h	6:39 h	10:11 h
Dimensões do <i>pixel</i>	6,25 m	12,5 m	-
Resolução espacial	8 m	25 m	30 m
Área de cobertura	50 km	100 km	185 km
Formato do dado	CEOS	CEOS	Geo tiff

<sup>1</sup>RADARSAT Internacional (1995)

## Correção geométrica das imagens

Afim de integrar as imagens de forma que elas ficassem uniformes quanto ao posicionamento de áreas e objetos, efetuou-se a correção geométrica das imagens utilizando o método da ortorretificação. A ortorretificação é baseada no modelo fotogramétrico e é mais precisa do que correções geométricas baseadas em modelos polinomiais (Toutin, 1999).

Na ortorretificação, utiliza-se o Modelo Digital de Elevação - MDE para correção do deslocamento do relevo e dados das efemérides inerentes ao satélite contidos no arquivo CEOS das imagens utilizadas. O MDE foi gerado a partir de curvas de nível extraídas das folhas topográficas digitais no formato "raster" do IBGE, na escala 1:50.000 (INPE, 2003), a saber: Cruzália (SF-22-Z-A-IV-1), Macaraí (SF-22-Z-A-IV-2), Assis (SF-22-Z-A-V-1), Florínia (SF-22-Z-A-IV-4), Cândido Mota (SF-22-Z-A-V-3) e, Paranajá (SF-22-Z-A-IV-3; Figura 1).

A correção geométrica das folhas topográficas e a ortorretificação das imagens foram realizadas no módulo *orthoengine* do aplicativo PCI *Geomatics 7.0* (PCI).

As folhas topográficas foram georreferenciadas por pontos de controle adquiridos na grade de coordenadas destas, sendo reamostradas por polinômios de 1° e 2° graus e por interpolação convolução cúbica. O sistema de projeção utilizado foi o UTM, fuso 22° S e datum horizontal SAD69. Com as folhas topográficas georreferenciadas, o próximo passo foi a aquisição de pontos de controle comuns nas folhas e nas imagens a serem ortorretificadas.

Dentre os vários filtros disponíveis no aplicativo PCI, optou-se pelo filtro *Frost Enhanced* (Lopes, 1990) com janela 3x3, pois este apresentou melhor qualidade visual. O interpolador utilizado foi o vizinho mais próximo, pois este preserva o brilho original dos pixels das imagens (Richards, 1986).

## Interpretação visual das imagens ETM+, F5A, S7D e definição das classes de estudo

Para a análise de textura em imagens monoespectrais, a escolha de um número elevado de classes não é apropriada, pois só aumenta a confusão entre as classes (Rennó, 1995). Nesse sentido, foi realizada a interpretação visual da imagem ETM+ na composição falsa cor RGB 453 com o intuito de identificar as classes de uso do solo mais representativas na área de estudo. A combinação dos canais RGB com as bandas 4 (760 - 900 nm), 5 (1550 - 1750 nm) e 3 (630 -

690 nm) do satélite Landsat-7, correspondentes, respectivamente, às faixas do espectro eletromagnético infravermelho próximo (NIR), infravermelho de ondas curtas (SWIR) e do vermelho (visível), é comumente usada na interpretação de imagens de áreas agrícolas (Formaggio & Sanches, 2017). Nesta composição, por exemplo, talhões de soja em pleno desenvolvimento vegetativo, aparecem em tons de amarelo devido à alta reflectância no NIR e no SWIR, o que facilita a diferenciação desta classe com outras classes adjacentes.

O trabalho de campo realizado nos dias 23 e 24 de fevereiro de 2023 para o reconhecimento georreferenciado de alguns talhões de soja e cana-de-açúcar em fase fenológica avançada, validou o mapeamento destas classes feito na imagem ETM+.

Após a interpretação visual da imagem ETM+, amostras de talhões e áreas representativas de cada classe de maior ocorrência na área de estudo foram selecionados e vinculadas às imagens do F5A e S7D, onde se realizou uma análise visual e se definiu as classes para posterior coleta de amostras de treinamento e teste. As amostras de treinamento foram utilizadas para a geração das medidas de textura e as amostras de teste foram utilizadas como referência para avaliar os resultados obtidos nas classificações digitais. A extração das amostras de treinamento e teste foi composta de vários polígonos retangulares (contendo aproximadamente 225 pixels) nas imagens F5A e S7D originais, dentro das parcelas das classes selecionadas.

## Medidas de textura

Segundo Haralick et al. (1973), a textura e a tonalidade estão sempre presentes em uma imagem e são propriedades intrinsecamente relacionadas, embora uma propriedade possa dominar sobre a outra. Quando uma área pequena de uma imagem tem pouca variação de níveis de cinza, a propriedade dominante é a tonalidade, caso contrário, a propriedade dominante é a textura.

O reconhecimento de padrões de textura é fácil de ser executado por intérpretes humanos, pois eles usam processos cognitivos complexos que ainda não são bem entendidos, mas é muito difícil quando se trata de um processo automatizado, pois não existe uma definição matemática precisa para a textura (Greenspan et al., 1994; Haralick, 1979; Mather, 1999).

Dois métodos de análise de textura são os mais utilizados: a análise estrutural e a análise

estatística (Haralick, 1979). Os métodos estatísticos de primeira ordem (Hsu, 1978; Irons & Peterson, 1981) são os que não levam em consideração a distribuição espacial dos níveis de cinza de uma área da imagem. Já os métodos estatísticos de segunda ordem como a matriz de co-ocorrência de nível de cinza (*Gray Level Co-occurrence Matrix* – GLCM; Haralick et al., 1973) representa a distância e as relações espaciais angulares sobre uma sub-região de uma imagem de tamanho especificado. Cada elemento da GLCM é uma medida de probabilidade de ocorrência de valores de níveis de cinza separados por uma dada distância numa dada direção (Mather, 1999).

O principal entrave do uso da GLCM é a grande demanda e tempo computacional, então, como alternativa, utiliza-se vetores soma e diferença de níveis de cinza. Detalhes das descrições teóricas e matemáticas da GLCM, bem como dos vetores soma e diferença de níveis de cinza são encontrados em outros trabalhos e referências citadas (Haralick et al., 1973; Haralick, 1979; Unser, 1986; Rennó, 1995; Soares et al., 1997).

A utilização de todas as medidas de textura na caracterização de um alvo é impraticável e desnecessária uma vez que a demanda computacional para extração dessas informações seria extremamente elevada e, devido à alta correlação existente entre várias dessas medidas, haveria muita informação redundante que poderia ser descartada (Rennó, 1995). Desse modo, faz-se necessária a adoção de um critério para a seleção das melhores medidas de textura, ou seja, aquelas que melhor discriminem os alvos de interesse.

O potencial de discriminação entre classes de interesse foi avaliado através do fator discriminante  $F_d$ . O  $F_d$  para duas classes, 1 e 2, para uma determinada medida hipotética  $A$ , é definido pela Equação 1. A situação ideal para um bom valor discriminante é aquela onde o desvio padrão da medida  $A$  para as classes 1 e 2 ( $S_{11}$  e  $S_{22}$ ) é pequeno e o desvio padrão da medida  $A$  entre as classes 1 e 2 ( $S_{12}$  e  $S_{21}$ ) é grande. Quanto maior o valor de  $F_d$  maior será o potencial discriminador da medida.

$$F_d = \frac{S_{12} + S_{21}}{S_{11} + S_{22}}(1)$$

Sendo,

$$S_{11} = \sum \frac{(VA_1 - m_1)^2}{n_1}(2)$$

$$S_{22} = \sum \frac{(VA_2 - m_2)^2}{n_2}(3)$$

$$S_{12} = \sum \frac{(VA_1 - m_2)^2}{n_1}(4)$$

$$S_{21} = \sum \frac{(VA_2 - m_1)^2}{n_2}(5)$$

onde:

$VA_1$  = valores de  $A$  para classe 1;  $VA_2$  = valores de  $A$  para classe 2;  $m_1$  = média da medida  $A$  para classe 1;  $m_2$  = média da medida  $A$  para classe 2;  $n_1$  = número de valores para classe 1 e;  $n_2$  = número de valores para classe 2.

Após a extração das amostras de treinamento das imagens F5A e S7D, foram geradas as medidas de textura de primeira ordem e GLCM no aplicativo *Texture* (Rennó, 2003). As medidas de primeira ordem geradas foram: desvio médio absoluto, *skewness*, curtose, coeficiente de variação, média, entropia e energia.

As medidas GLCM geradas foram: contraste, entropia, energia, homogeneidade, correlação, dissimilaridade, chi-quadrado, *cluster shade*, *cluster prominence*, média do vetor soma, variância do vetor soma, entropia do vetor soma, energia do vetor soma, média do vetor diferença, variância do vetor diferença, entropia do vetor diferença, energia do vetor diferença e contraste do vetor diferença.

Os parâmetros de entrada requeridos para geração das medidas GLCM no programa *Texture* são: 1) número de quantização dos níveis de cinza; 2) a direção do vetor deslocamento; e 3) a vizinhança para o cálculo da medida. Foram realizados testes com quantização de níveis de cinza de 64, 128 e 256 e verificou-se que os níveis de cinza iguais a 256 e 128 apresentaram os melhores resultados. Optou-se pelo nível de cinza igual a 128, pois esse apresentou um tempo computacional menor.

A direção do vetor de deslocamento utilizada foi a omnidirecional e a vizinhança igual a 1, ou seja, o nível de cinza de um determinado pixel foi comparado com níveis de cinza dos 8 pixels vizinhos mais próximos. Além das imagens originais, imagens filtradas foram utilizadas. Os filtros para redução do *speckle Frost*, *Lee* e *Gamma* (Frost et al., 1982; Lee, 1980; Lopes et al., 1993) com janelas 3 x 3, 5 x 5, e 7 x 7 foram aplicados e testados, de modo que a janela 5 x 5 apresentou melhor resultado para todos os filtros.

Assim, as imagens submetidas às análises de textura foram: 1) Imagem original; 2) Imagem filtrada *Frost* 5 x 5; 3) Imagem filtrada *Gamma* 5

x 5 e; 4) Imagem filtrada de *Lee* 5 x 5. O programa *Texture* gerou então uma camada de medidas correspondente a cada imagem.

As melhores medidas de textura para cada par de classes corresponderam aos maiores valores de *Fd* gerados pelo *Texture*. Com as melhores medidas selecionadas, as bandas de textura foram geradas no programa *Filter texture* que utiliza um método de filtragem espacial e requer, além dos parâmetros de entrada para a geração das medidas GLCM citados acima, o tamanho da janela de aquisição das medidas de textura (Van Der Sanden, 1997).

A janela escolhida foi a 5 x 5, pois esta apresentou um tempo computacional menor. Cabe mencionar, que as imagens F5A e S7D originais (CEOS), foram transformadas do formato *Float Point* (16 bits) para o formato *Byte* (8 bits) a fim de diminuir o tempo de processamento computacional e o tamanho dos arquivos.

### **Classificação digital das imagens**

Primeiramente, foram realizadas as classificações das imagens F5A e S7D originais, em seguida das imagens filtradas e por último das imagens de textura, que foram classificadas pelo método de classificação pontual/contextual (Máxima Verossimilhança/ICM) no programa MAXVER/ICM desenvolvido em ambiente ENVI 3.4 (Vieira, 1996). O programa permite o ajuste das seguintes distribuições: Normal; Raiz quadrada da Gama; Amplitude; Amplitude G0;

Log normal e Weibull (Vieira et al., 1997). Após o procedimento das classificações foram construídas matrizes de confusão através de amostras de testes, utilizadas como dado de referência, para avaliar a quantidade de pixels classificados correta e incorretamente. A proporção de amostras corretamente classificadas corresponde à razão entre a soma da diagonal principal da matriz de confusão (amostras corretamente classificadas) e a soma de todos os elementos desta matriz (número total de amostras).

O método utilizado para avaliar a exatidão da classificação com matrizes de confusão foi o coeficiente de concordância *Kappa* (Rosenfield & Fitzpatrick, 1986; Hudson & Ramm, 1987; Foody, 1992). Este tem a vantagem de levar em consideração todos os elementos da matriz de confusão e não somente os elementos da diagonal. Portanto o coeficiente *Kappa* estima a proporção de acerto que efetivamente ocorre.

O coeficiente *Kappa* pode assumir valores menores ou iguais a 1, podendo inclusive ter valores negativos. Quando todas as amostras são corretamente classificadas, ou seja, todos os elementos da matriz de confusão fora da diagonal possuem valores nulos, o coeficiente *Kappa* possui valor 1. Landis e Koch (1977) propuseram seis conceitos de eficiência ao *Kappa*, ou seja,  $0 -$  péssima;  $0 < k \leq 0,2 -$  má;  $0,2 < k \leq 0,4 -$  razoável;  $0,4 < k \leq 0,6 -$  boa;  $0,6 < k \leq 0,8 -$  muito boa; e  $0,8 < k \leq 1,0 -$  excelente.

## **RESULTADOS E DISCUSSÃO**

### **Interpretação da imagem ETM+ e análise visual das imagens F5A E S7D**

Com as informações obtidas em campo e a interpretação visual da imagem ETM+, as principais classes de uso do solo foram extensas áreas de soja, cana-de-açúcar e solo exposto. incluindo solo preparado e palhada.

Outras classes menos predominantes foram áreas de milho, banana, campo sujo e pastagens, mata nativa, água e áreas urbanas. As classes que mais se diferenciaram na análise visual das imagens F5A e S7D foram as áreas urbanizadas, água, soja, cana-de-açúcar, solo exposto e palhada. A figura 2 mostra exemplos de talhões de cana-de-açúcar, soja e solo exposto nas imagens ETM+, F5A e S7D.

As áreas de cana-de-açúcar apresentaram grande diversidade de estádios fenológicos, arquitetura e altura de plantas, e direção de linhas de plantio na área de estudo. Na figura 2, o talhão de

cana-de-açúcar vermelho-escuro na imagem ETM+ corresponde a uma variedade de cana-de-açúcar de arquitetura erectófila, cuja orientação dos caules e das folhas são predominantemente verticais. Já os talhões adjacentes de coloração vermelho-claro representam uma variedade de cana-de-açúcar de arquitetura erectófila, cujas extremidades das folhas são dobradas. O talhão de cana-de-açúcar vermelho-escuro e os talhões vermelho-claro da imagem ETM+ apresentaram tons de cinza predominantemente escuros e intermediários nas imagens F5A e S7D, respectivamente.

As culturas de ambas variedades de cana-de-açúcar se encontram em estágio de crescimento avançado, com dossel fechado cobrindo totalmente o solo, eliminando o efeito da linha de plantio e de solo-planta, que poderia causar *double bounce*, atenuando, assim, o retroespalhamento. Porém, a variedade de cana-de-açúcar com caules e folhas verticais tem uma menor atenuação da radiação

	Cana-de-açúcar		Soja	Solo exposto
<b>Fotos (24 e 25/02/2003)</b>			<b>Não disponível</b>	
<b>ETM+ RGB 453 (23/02/2003)</b>				
<b>S7D (23/02/2003)</b>				
<b>F5A (14/02/2003)</b>				

**Figura 2** - Exemplo de talhões de cana-de-açúcar, soja e solo exposto nas imagens ETM+ RGB 453, S7D e F5A.

incidente polarizada horizontalmente (HH), o que poderia justificar a diminuição do retroespalhamento e, conseqüentemente, uma tonalidade mais escura (Dobson et al., 1995; Ulaby et al., 1982). Na imagem S7D (passagem diurna), a tonalidade mais clara dos talhões de cana-de-açúcar com as extremidades das folhas dobradas em relação a imagem F5A (passagem noturna) pode ser atribuída à influência do orvalho, que aumenta o retroespalhamento (Wood et al., 2002).

Para a cultura de soja, o talhão circundado predominantemente por talhões de cana-de-açúcar aparece em tons de amarelo na imagem ETM+ e, assim como a cana-de-açúcar, se encontra na fase de máximo desenvolvimento, com dossel fechado

cobrindo o solo, eliminando o efeito da direção de plantio e solo-planta no retroespalhamento, de modo que o retroespalhamento é atenuado pela superfície do dossel, resultando num tom de cinza mais escuro em relação aos alvos agrícolas circundantes.

O talhão de solo exposto em tons de azul escuro na imagem ETM+ apresentou heterogeneidade de tons de cinza nas imagens F5A e S7D, isto é, tons claros, intermediário e escuro. Para uma área de solo exposto, as características que governam a refletividade SAR são o teor de umidade do solo e a rugosidade superficial (Ulaby et al., 1986b). O comportamento dessa classe seria determinado primeiramente pelo teor

de umidade do solo e, em segundo lugar, pela rugosidade para a banda C para ângulos de incidência menores que 30° (Dobson & Ulaby, 1981).

Como os ângulos das imagens F5A e S7D variam entre 44,7° a 49,2°, a influência da umidade do solo no retroespalhamento do talhão em questão diminui em importância. As áreas com solo exposto que não foram aradas ou gradeadas têm baixa rugosidade, conseqüentemente, são consideradas lisas pelo sensor e possuem baixo retroespalhamento, aparecendo sempre em tons escuros. A presença de sulcos nos solos nus preparados para o plantio aumenta a rugosidade, aumentando, portanto, o retroespalhamento destas áreas, que aparecem nas imagens com tons de cinza mais claros. A direção de linha de sulcamento ou de plantio em relação à direção de imageamento também condiciona o comportamento destas áreas.

Áreas com sulcos perpendiculares ao sentido de imageamento têm normalmente retroespalhamento maior que áreas com o mesmo tipo de preparo do solo, mas com sulcos paralelos ao sentido do imageamento (Ulaby et al., 1986b; Formaggio et al., 2001).

Outras classes, como água, área urbana e palhada, apresentaram homogeneidade nos tons de cinza para todas as imagens F5A e S7D. A classe água apresentou tom de cinza escuro característico. A classe área urbana apresentou tom de cinza claro com uma textura característica e a classe solo palha tons de cinza intermediários a claros.

### Definição das classes de estudo e coleta de amostras de treinamento e teste

Como discutido previamente, a análise visual das imagens F5A e S7D mostrou heterogeneidade de tons de cinza entre uma mesma classe. Assim, para evitar uma variância muito elevada de uma mesma classe, dividiram-se as mesmas em subclasses resultando num total de 9, a saber: 1) água (rios e lagos); 2) área urbana; 3) soja; 4) cana-de-açúcar-1 (tonalidade escura); 5) cana-de-açúcar-2 (tonalidade intermediária); 6) solo exposto-1 (tonalidade escura); 7) solo exposto-2 (tonalidade intermediária); 8) solo exposto-3 (tonalidade clara); e 9) palhada. Amostras de treinamento e teste correspondentes às nove subclasses foram coletadas das imagens F5A e S7D originais dentro de parcelas das classes selecionadas, sendo que o conjunto de amostras foi submetido a uma avaliação estatística através da média e do desvio padrão dos níveis de cinza (0 a 255), com o intuito de avaliar a amostragem realizada (Tabela 2).

Pela análise da tabela 2, observa-se que a média e o desvio padrão dos níveis de cinza das amostras de treinamento e teste foram praticamente iguais para as imagens F5A e S7D, o que mostra que a amostragem foi apropriada. Para a imagem S7D, as médias apresentaram maiores valores para todas as classes em relação à imagem F5A, provavelmente porque a imagem S7D apresenta resolução espacial inferior, que torna os tons de cinza mais suavizados.

**Tabela 2** - Valores da média e desvio padrão dos níveis de cinza de amostras de treinamento (ATr) e teste (ATe).

Subclasse	F5A		S7D	
	ATe	ATr	ATe	ATr
Água	16,3 (± 9)	16,5 (± 9)	20,6 (± 5)	20,5 (± 5)
Área urbana	123,3 (± 74)	121 (± 73)	188 (± 55)	185 (± 55)
Cana-de-açúcar-1	69,6 (± 38)	69,2 (± 38)	86,1 (± 25)	89,5 (± 26)
Cana-de-açúcar-2	92,6 (± 49)	92,9 (± 49)	130 (± 35)	130 (± 35)
Soja	76,1 (± 40)	76 (± 40)	117 (± 32)	117 (± 32)
Solo exposto-1	40,2 (± 23)	40,1 (± 24)	59,4 (± 24)	59 (± 24)
Solo exposto-2	102,9 (± 56)	101 (± 54)	146 (± 45)	143 (± 43)
Solo exposto-3	63,2 (± 35)	62,6 (± 34)	101 (± 29)	102 (± 30)
Palhada	108,9 (± 58)	110 (± 58)	124 (± 34)	124 (± 34)

### Seleção das medidas de textura com maior potencial de discriminação

Após a análise das todas as 7 medidas de textura de primeira ordem e das 18 medidas GLCM disponíveis no aplicativo Texture, foram geradas as bandas de textura que corresponderam

às que apresentaram melhor discriminação. Para a imagem F5A, uma medida de textura de primeira ordem (média) e 7 medidas GLCM foram selecionadas entre as quais apresentaram maior potencial de discriminação para 28 pares de classe analisados (Tabela 3).

**Tabela 3** - Medidas selecionadas pelo fator discriminante  $F_d$  para a imagem F5A.

<b>Medidas de textura</b>	<b>Par de classes</b>	<b><math>F_d</math></b>
<b>Energia do vetor diferença</b>	S e C1	2,13
	S e SE1	51,14
	S e SE3	9,6
<b>Cluster Prominence</b>	AU e S	370,4
	S e SE2	30,6
	AU e C1	227,4
	AU e C2	52,54
	AU e SE2	14,5
	AU e SE3	102,6
	AU e SP	16,03
	C1 e SE2	23,42
	C1 e SE1	18,14
<b>Entropia do vetor diferença</b>	C1 e SE1	18,14
<b>Variância do vetor diferença</b>	S e C2	10,08
	S e SP	33,44
	AU e SE1	187,6
	C1 e C2	10,3
	C1 e SP	24,55
	C2 e SE3	16,2
	SE1 e SE2	70,41
	SE2 e SE3	20,72
	SE3 e SP	19,21
<b>Entropia (Frost 5x5)</b>	C1 e SE3	3,1
<b>Entropia</b>	C2 e SE2	7,96
<b>Média (Frost 5x5)</b>	SE1 e SE3	8,18
<b>Média (Lee 5x5)</b>	SE2 e SP	1,58
<b>Contraste do vetor diferença</b>	C2 e SE1	57,06
	SE1 e SP	78,95
<b>Chi-quadrado</b>	C2 e SP	4,69

**Legenda:** AU - Área urbana, C1 - Cana-de-açúcar-1, C2 - Cana-de-açúcar-2, S - Soja, SE1 - Solo exposto-1, SE2 - Solo exposto-2, SE3 - Solo exposto-3 e SP - Palhada.

As medidas de textura “energia do vetor diferença”, “cluster prominence”, “entropia do vetor diferença”, “variância do vetor diferença”, “entropia” (esta última somente para as classes C2/SE2), “contraste do vetor diferença” e “chi-quadrado” apresentaram os melhores resultados quando aplicadas à imagem original. As medidas de textura “entropia” e “média” apresentaram maior potencial de discriminação quando aplicadas os filtros *Frost 5 x 5* e *Lee 5 x 5*, respectivamente.

Pela análise dos valores do fator discriminante  $F_d$  apresentados na tabela 3, pode-se observar que a medida “cluster prominence” apresentou alto potencial de discriminação para as classes AU/S, AU/C1 e AU/SE3. A medida “variância do vetor diferença” apresentou alto potencial de discriminação para as classes AU/SE1 e SE2/SE3, e a medida “contraste do vetor diferença” para a classe SE1/SP. As demais medidas e os pares de classes correspondentes apresentaram baixo potencial de discriminação. Dez imagens de textura correspondentes às medidas apresentadas na tabela 3 foram geradas. As imagens de textura “média” filtrada (*Frost 5 x 5*) e “Energia do vetor diferença” são mostradas na figura 3 como exemplo.

Para a imagem S7D, 10 medidas de textura (8 medidas GLCM e 2 medidas de primeira ordem (“desvio médio absoluto” e “média”) foram selecionadas entre as que apresentaram maior potencial de discriminação para 28 pares de classe analisados (Tabela 4).

As medidas de textura “energia do vetor diferença”, “contraste”, “média do vetor soma”, “homogeneidade”, “energia”, “variância do vetor diferença”, “desvio médio absoluto”, “média” (esta última somente para as classes SE1/SP), “chi-quadrado” e “média do vetor diferença” apresentaram os melhores resultados quando aplicadas à imagem original. A medida de textura “média” apresentou maior potencial de discriminação, ora quando aplicada à imagem com filtro *Frost 5 x 5*, ora na imagem filtrada *Gamma 5 x 5*. Doze imagens de textura correspondentes às medidas apresentadas na tabela 4 foram geradas. As imagens de textura “variância do vetor diferença” e “homogeneidade” são mostradas na figura 3 como exemplo. Pela análise dos valores do fator discriminante  $F_d$  apresentados na tabela 4, observa-se que a medida de textura “energia do vetor diferença”

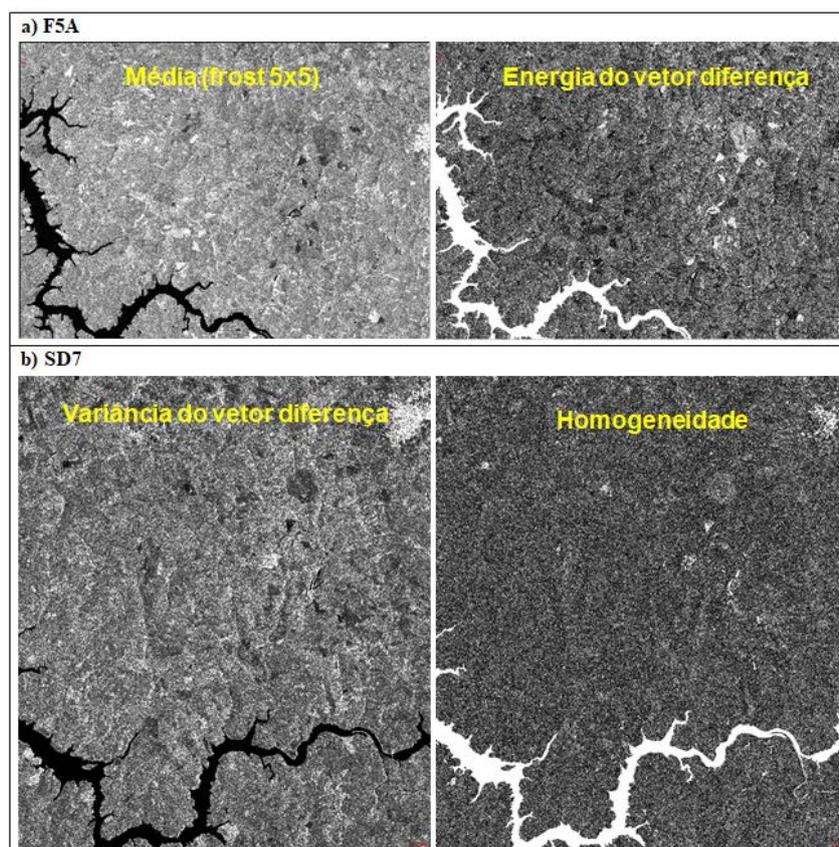


Figura 3 - Exemplo de imagens de textura derivadas das imagens FSA (a) e S7D (b).

Tabela 4 - Medidas selecionadas pelo fator discriminante  $F_d$  para a imagem SD7.

Medidas de textura	Par de classes	$F_d$
Energia do vetor diferença	S e C1	17,53
	S e SE1	138,29
Contraste	AU e S	212,68
Média do vetor soma	C1 e C2	21,73
Homogeneidade	C1 e SE1	13,12
	S e SE2	28,29
Energia	S e SE3	9,74
	C2 e SE2	12,51
	AU e C1	99,98
	AU e C2	100
Variância do vetor diferença	AU e SE1	100
	AU e SP	100
	C1 e SE2	32,74
	AU e SE2	9,37
Desvio da média absoluto	SE3 e SP	5,48
Média (Gama 5x5)	C1 e SE3	3,3
	C1 e SP	17,8
	C2 e SE1	63,64
Média (Frost 5x5)	C2 e SE3	11,1
	C2 e SP	1,53
	SE1 e SE3	15,1
	C2 e S	3,86
Média	SE1 e SP	28,99
Chi-quadrado	S e SP	3,34
Média do vetor diferença	AU e SE3	48,65
	SE1 e SE2	27,8
	SE2 e SE3	12,05
	SE2 e SP	3,71

**Legenda:** AU - Área urbana, C1 - Cana-de-açúcar-1, C2 - Cana-de-açúcar-2, S - Soja, SE1 - Solo exposto-1, SE2 - Solo exposto-2, SE3 - Solo exposto-3 e SP - Palhada.

apresentou alto potencial de discriminação para a classe S/SE1, a medida “contraste” para a classe AU/S, a medida “variância do vetor diferença” para as classes AU/C1, AU/C2, AU/SE1 e AU/SP, a medida “média” para a classe C2/SE1. As demais medidas e os pares de classe correspondentes apresentaram baixo potencial de discriminação.

### Classificação das imagens F5A E SD7

Foram realizadas classificações das imagens F5A e S7D originais, filtradas e de textura derivadas destas. O algoritmo ICM foi utilizado para a classificação, de modo que cada classe foi ajustada às seguintes distribuições estatísticas: Raiz Quadrada da Gama; Normal; Log normal ou Weibull.

### Imagem F5A

A figura 4 ilustra as classificações das imagens F5A original e filtrada *Gamma* 5 x 5 e as tabelas 5 e 6 apresentam a matriz de confusão e o valor *kappa* para as classificações das imagens F5A original e *Gamma* 5 x 5, respectivamente. Os filtros *Frost* 5 x 5, *Gamma* 5 x 5 e *Lee* 5 x 5 de redução do ruído *speckle* foram aplicados à imagem F5A original e realizada a classificação para cada imagem filtrada. A imagem F5A filtrada *Gamma* 5 x 5 foi a que apresentou melhor resultado em relação às classificações realizadas com os outros dois filtros. As classificações das imagens filtradas apresentaram, em geral, melhores resultados que a classificação na imagem original.

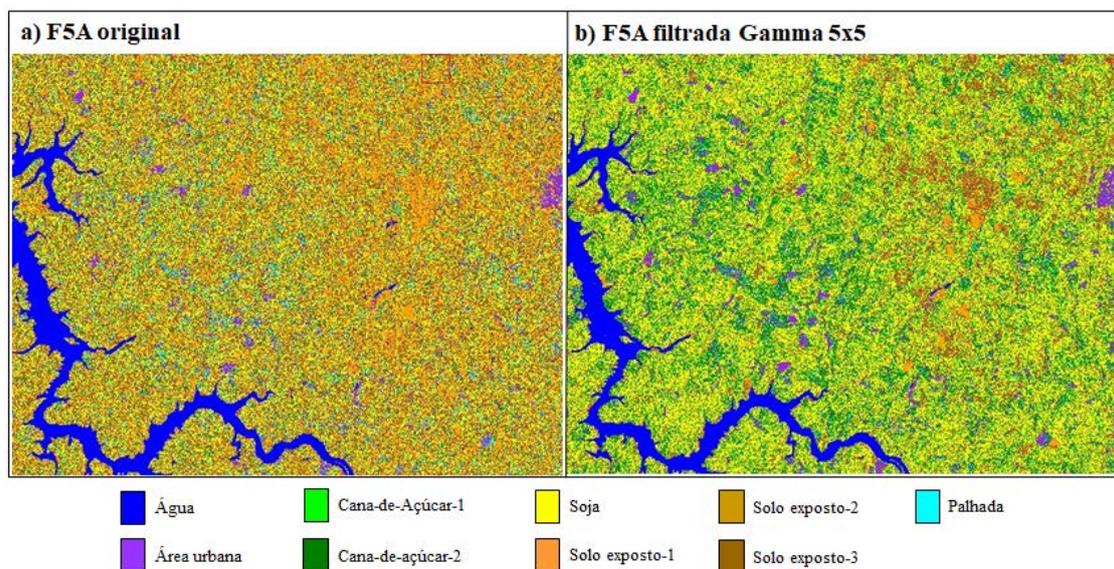


Figura 4 - Resultado das classificações das imagens F5A original (a) e F5A filtrada *Gamma* 5 x 5 (b).

Tabela 5 - Matriz de confusão da classificação da imagem F5A original em %.

Subclasse	Água	Área urbana	Cana-de-açúcar1	Cana-de-açúcar2	Soja	Solo exposto1	Solo exposto2	Solo exposto3	Palhada	Total
Água	100	0,02	0,09	0,02	0,05	10,98	0,08	0,11	0,03	2,24
Área urbana	0	67,3	0,42	8,25	0,6	0,02	21,4	0,15	34,1	5,61
Cana-de-açúcar-1	0	0	0,22	0,19	0,25	0	0,05	0,17	0,09	0,19
Cana-de-açúcar-2	0	2,91	4,72	13,15	7,92	0,02	9,21	3,14	8,57	6,52
Soja	0	7,53	24,13	26,51	32,5	0,42	22	15,9	13,4	24,3
Solo exposto-1	0	3,83	31,48	5,92	18,3	83,43	4,49	48,5	1,71	25,1
Solo exposto-2	0	4	3,18	13,83	5,6	0,03	13,1	1,48	14,7	5,49
Solo exposto-3	0	5,95	33,44	15,22	30,3	5,1	10,3	29,7	6,45	25,1
Palhada	0	8,43	2,32	16,22	4,42	0	19,4	0,87	20,9	5,57
Total	100	100	100	100	100	100	100	100	100	100
Exatidão total	28,15%		<i>kappa</i>	0,155						

**Tabela 6** - Matriz de confusão da classificação da imagem F5A Gamma 5 x 5 em %.

Subclasse	Água	Área urbana	Cana-de-açúcar-1	Cana-de-açúcar-2	Soja	Solo exposto-1	Solo exposto-2	Solo exposto-3	Palhada	Total
Água	<b>99,8</b>	0	0	0	0	1,95	0	0	0	1,54
Área urbana	0	<b>80</b>	0,12	10,38	0,23	0	29,2	0,07	52,13	6,93
Cana-de-açúcar-1	0	0,46	<b>9,27</b>	0,58	6,94	0,07	0,38	8,63	0,13	5,76
Cana-de-açúcar-2	0	12,18	9,95	<b>61,32</b>	23,12	0,01	43,1	2,56	32,78	20,6
Soja	0	3,71	44,1	18,22	<b>56,66</b>	0,23	12,7	28,61	2,86	38,5
Solo exposto-1	0,25	0,05	2,91	0	0,1	<b>85,7</b>	0	13,28	0	7,68
Solo exposto-2	0	0,01	0	0,17	0,02	0	<b>0,16</b>	0	0,19	0,04
Solo exposto-3	0	0,59	33,4	0,21	12,55	12,05	0,18	<b>46,9</b>	0	17
Palhada	0	2,96	0,25	9,12	0,38	0	14,3	0	<b>11,9</b>	1,93
<b>Total</b>	100	100	100	100	100	100	100	100	100	100
<b>Exatidão total</b>	46,14%			<i>kappa</i>	0,313					

A exatidão total (28,15%) e o valor *kappa* (0,155) para a classificação da imagem F5A original mostra uma classificação geral ruim. Com exceção das classes água, área urbana e solo exposto-1, que foram bem discriminadas, as demais classes apresentaram discriminação ruim, abaixo de 50% (Tabela 5).

A classificação sobre a imagem F5A filtrada *Gamma 5 x 5* mostra uma performance razoável com exatidão total de 46,14% e valor *kappa* de 0,313. As classes água, área urbana, cana-de-açúcar-2, soja e solo exposto-1 apresentaram boa discriminação com porcentagem de acerto de 99,8%, 80%, 61,32, 56,66 e 85,7%, respectivamente. As demais classes apresentaram baixa discriminação com porcentagem de acerto abaixo de 50% (Tabela 6).

A tabela 7 apresenta o resultado das classificações das classes por imagem de textura, os valores *kappa* e a exatidão total extraídos da matriz de confusão de cada classificação. Os valores destacados em negrito na tabela 7 indicam as classes melhores classificadas por imagem de textura. Com exceção da classe solo exposto-1, as demais classes apresentaram maior discriminação quando comparados à imagem F5A filtrada *Gamma 5 x 5*, entretanto, a exatidão total e o valor *kappa* das classificações apresentaram valores inferiores a esta. As classes palhada, área urbana, cana-de-açúcar-2 apresentaram alta discriminação com valores maximizados para as classificações das imagens de textura ‘chi-quadrado’, “variância do vetor diferença” e “entropia (*Frost 5 x 5*)”, respectivamente.

**Tabela 7** - Resultado das classificações de imagens de textura F5A em %.

Subclasse	Chi-quadrado	Energia do vetor diferença	Cluster prominence	Contraste do vetor diferença	Entropia do vetor diferença	Variância do vetor diferença	Entropia ( <i>Frost5x5</i> )	Média ( <i>Lee5x5</i> )	Entropia	Média ( <i>Frost5x5</i> )
Água	99,85	99,8	-	99,73	61,58	<b>99,88</b>	95	99,67	95	99,87
Área urbana	0,65	0,68	91,9	89,32	2,27	<b>92,42</b>	9,27	61,13	1,82	67,09
Cana-de-açúcar1	0,35	5,57	0	5,01	3,61	5,86	0,96	7,17	0	<b>9,92</b>
Cana-de-açúcar2	0,07	12,08	18,6	36,86	21,01	28,73	<b>92,64</b>	43,42	86,67	57,38
Soja	3,96	37,1	<b>64,5</b>	48,39	44,1	47,72	3,81	45,35	2,11	49,76
Solo exposto1	79,56	75,3	77,5	78,38	27,35	79,76	57,78	78,9	5,53	<b>81,09</b>
Solo exposto2	0	0	0	0	0	0	0	0,6	0	<b>0,61</b>
Solo exposto3	19,72	45,59	20	49,9	0	48,35	19,46	49,45	16,71	<b>51,63</b>
Solo palha	<b>97,14</b>	89,15	22,9	16,35	80,98	7,54	2,74	25,38	5,42	28,15
<b>Exatidão total (%)</b>	13,87	31,33	41,16	39,58	27,6	38,53	14,6	38,61	15,39	43,07
<i>kappa</i>	0,084	0,1784	0,2225	0,2495	0,127	0,2377	0,0587	0,2393	0,07	0,2874

Para as classes soja, cana-de-açúcar-1, solo exposto-2 e solo exposto-3, os valores indicam ligeira melhora quando comparados à classificação da imagem F5A filtrada *Gamma* 5 x 5. As classes cana-de-açúcar-1 e solo exposto-2 apresentaram valores de discriminação muito baixos para todas as classificações. A classificação que apresentou a melhor exatidão total (43,07%) e valor *kappa* (0,2874) foi a “média (*Frost* 5 x 5)”,

considerada razoável no conceito de eficiência *kappa*.

#### Imagem S7D

A figura 5 ilustra as classificações das imagens S7D original e filtrada *Gamma* 5 x 5 e as tabelas 8 e 9 apresentam a matriz de confusão e o valor *kappa* para as classificações das imagens S7D original e *Gamma* 5 x 5, respectivamente.

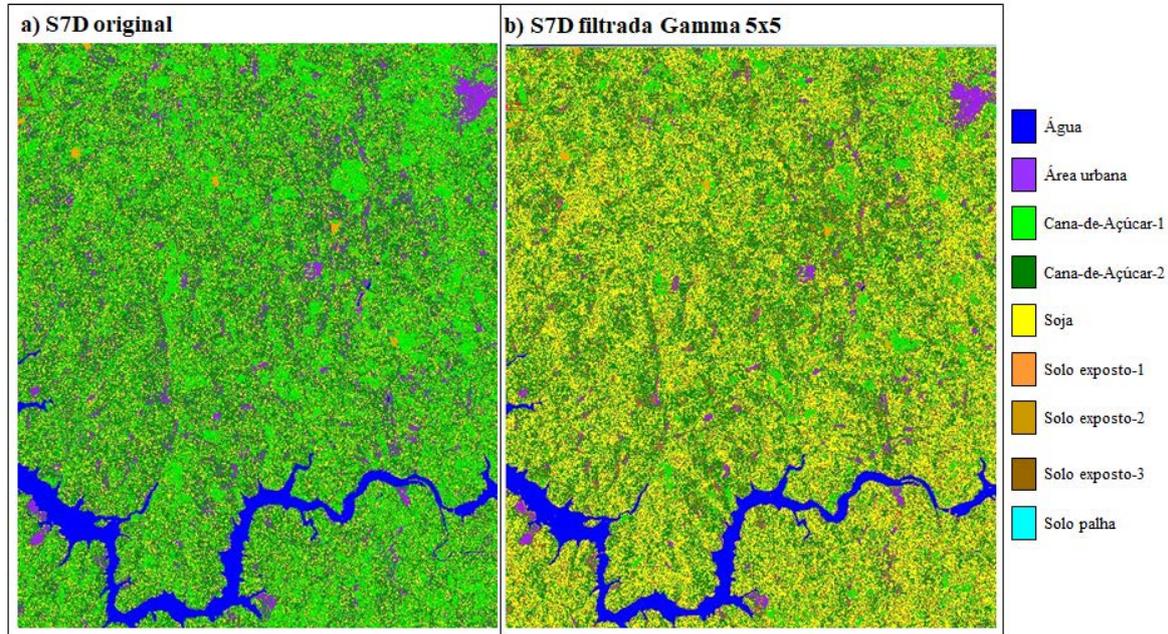


Figura 5 - Resultado das classificações das imagens SD7 original (a) e SD7 filtrada *Gamma* 5x5 (b).

Os filtros *Frost* 5 x 5, *Gamma* 5 x 5 e *Lee* 5 x 5 de redução do ruído *speckle* foram testados e, assim como na imagem F5A, o filtro *Gamma* 5 x 5 foi a que apresentou melhor resultado em relação às classificações realizadas com os outros dois filtros.

As classificações nas imagens filtradas apresentaram, em geral, melhores resultados que a classificação da imagem S7D original.

A exatidão total (40,76%) e valor *kappa* (0,257) indica uma classificação geral razoável. As classes soja e solo exposto-3 apresentaram discriminação ruim com valores abaixo de 50%. As classes de solo exposto-2 e palhada apresentaram 100% de confusão. As demais classes, isto é, água, área urbana, cana-de-açúcar-1, cana-de-açúcar-2 e solo exposto-1, apresentaram boa discriminação (Tabela 8).

Tabela 8 - Matriz de confusão da imagem S7D original em %.

Subclasse	Água	Área urbana	Cana-de-açúcar1	Cana-de-açúcar2	Soja	Solo exposto1	Solo exposto2	Solo exposto3	Palhada	Total
Água	100	0	0	0	0	0,1	0	0	0	3,76
Área urbana	0	89,5	0,04	9,83	3,14	0,2	32,4	1,1	9,37	9,12
Cana-de-açúcar-1	0	1,38	83,6	13,09	31,69	18,7	9,23	64,5	19,4	28,1
Cana-de-açúcar-2	0	7,4	2,9	53,66	33,26	0,9	38,9	13	41,5	33,3
Soja	0	1,35	3,32	17,49	22,57	0	14,8	13,1	22,1	17,3
Solo exposto-1	0	0,06	8,17	0,12	0,23	80,1	0,37	2,47	0,25	1,87
Solo exposto-2	0	0	0	0	0	0	0	0	0	0
Solo exposto-3	0	0,36	1,95	5,81	9,11	0	4,35	5,89	7,36	6,64
Palhada	0	0	0	0	0	0	0	0	0	0
Total	100	100	100	100	100	100	100	100	100	100
Exatidão total	40,76%		<i>kappa</i>		0,257					

A classificação sobre a imagem S7D com o filtro *Gamma* 5 x 5 mostrou uma performance razoável com exatidão total de 56,48% e valor *kappa* de 0,393. A classificação sobre a imagem filtrada, assim como na imagem F5A, apresentou resultado consideravelmente melhor que a imagem original. As classes água, área urbana, cana-de-açúcar-1, cana-de-açúcar-2, soja e solo

exposto-1 apresentaram boa discriminação com porcentagem de acerto de 100%, 89,4%, 65,9, 53,75 e 55,11%, respectivamente.

As classes de solo exposto-2 e solo exposto-3 apresentaram baixa discriminação com porcentagem de acerto bem abaixo de 50%. A classe palhada apresentou porcentagem de 100% de confusão (Tabela 9).

**Tabela 9** - Matriz de confusão da imagem S7D filtrada de Gamma 5 x 5 em %.

Subclasse	Água	Área urbana	Cana-de-açúcar-1	Cana-de-açúcar-2	Soja	Solo exposto-1	Solo exposto-2	Solo exposto-3	Palhada	Total
Água	100	0	0	0	0	0	0	0	0	3,75
Área urbana	0	89,4	0	1,74	0,11	0	23,6	0	0,45	5,11
Cana-de-açúcar-1	0	0	65,9	0,67	3,38	23	0,37	32	1,8	7,9
Cana-de-açúcar-2	0	6,24	0,14	53,75	27,81	0	41,3	7,68	45,1	30,2
Soja	0	0,43	9,77	28,14	55,11	0,15	18,2	36,6	42,1	37,9
Solo exposto-1	0,03	0	6,64	0	0	75,8	0	1,36	0	1,51
Solo exposto-2	0	3,96	0,03	12,44	1,22	0	16,1	0,16	5,89	4,49
Solo exposto-3	0	0	17,6	3,24	12,36	1,05	0,49	22,3	4,66	9,09
Palhada	0	0	0	0,02	0,01	0	0	0	0	0,01
Total	100	100	100	100	100	100	100	100	100	100
Exatidão total	56,48%			<i>kappa</i>	0,393					

As classificações das imagens S7D apresentaram valores de exatidão total e *kappa* maiores do que a imagem F5A. Este resultado provavelmente ocorreu porque a imagem S7D apresenta menos efeito do ruído *speckle*, por conter um maior número de *looks* (Tabela 1), o que resulta num melhor desempenho em relação à imagem F5A, de apenas 1 *look*.

A tabela 10 mostra o resultado da classificação das classes por imagem de textura, os valores *kappa* e a exatidão total extraídos da

matriz de confusão de cada classificação. No total, foram geradas 12 imagens de textura selecionadas a partir das imagens filtradas e da imagem original. Entretanto, apenas 9 dessas imagens estão representadas na tabela 10, pois estas apresentaram os melhores resultados de classificação. As imagens de textura “contraste”, “energia do vetor diferença” e “homogeneidade” apresentaram desempenho muito baixo com valores de exatidão total abaixo de 10% e valores *kappa* negativos.

**Tabela 10** - Resultado das classificações de imagens de textura S7D em %.

Subclasse	Chi-quadrado	Média do vetor diferença	Variância do vetor diferença	Energia	Média (Frost5x5)	Média	Desvio médio absoluto	Média (Gamma5x5)	Média do vetor soma
Água	99,74	99,9	99,67		100	99,98	100	99,97	100
Área urbana	0	90,12	91,12	0	91,15	86,51	88,99		77,39
Cana-de-açúcar-1	21,22	57,56	57,71	0,18	67,66	72,23	74,04	64,75	60,8
Cana-de-açúcar-2	4,1	18,7	14,87	65,08	50,83	43,71	59,18	50,5	54,44
Soja	0	33,95	36,13	0	52,26	35,3	42,15	57,38	52,91
Solo exposto-1	75,52	60,27	60,02	90,18	74,38	78,12	77,37	75,82	74,83
Solo exposto-2	65,81	23,17	24,97	0	6,6	9,8	0	41,04	0
Solo exposto-3	10,08	10,61	9,08	0	16,48	14,92	12,77	23,08	24,88
Palhada	25,19	0	0	1,6	0,16	8,59	1,64	0,57	0,12
Exatidão total	9,12	35,5	35,58	19,43	54,13	44,06	51,52	55,5	54,47
<i>kappa</i>	0,06	0,193	0,193	0,042	0,363	0,278	0,344	0,355	0,367

Os valores destacados em negrito na tabela 10 indicam as classes mais bem classificadas por imagem de textura. As classificações sobre as imagens de textura indicaram uma melhora na discriminação de todas as classes em relação à classificação da imagem S7D com o filtro *Gamma* 5 x 5. Entretanto, a exatidão total e o valor de *kappa* foram inferiores à imagem filtrada *Gamma* 5 x 5, assim como na imagem F5A.

A classificação que apresentou a melhor exatidão total e valor *kappa* foi a média (*Gamma*

5 x 5), com valores de 55,5% e 0,355, respectivamente, considerada boa no conceito de eficiência *kappa*.

Em geral, as classificações realizadas sobre as imagens de textura S7D selecionadas a partir da imagem original apresentaram valores de discriminação ligeiramente inferiores em relação às classificações realizadas sobre as imagens de textura derivadas da F5A. Isso pode ter ocorrido devido à resolução espacial inferior da imagem S7D em relação à imagem F5A, o que acarreta numa perda de informação textural.

## CONCLUSÕES

Os resultados deste estudo mostraram que a aplicação de filtros adaptativos e atributo textural em imagens SAR melhoram a precisão das classificações digitais. A análise visual das imagens SAR/Radarsat-1, banda C e polarização HH nos modos F5A e S7D discriminaram variedades de cana-de-açúcar adultas erectófilas, com as extremidades das folhas verticais (tons de cinza escuro) e com as extremidades das folhas dobradas (tons de cinza intermediários), mostrando serem sensíveis às mudanças na estrutura das plantas na fase de máximo desenvolvimento.

Um talhão de soja, na fase de máximo desenvolvimento, apresentou tons de cinza mais escuros do que variedades de cana-de-açúcar circundantes na fase adulta, tanto na imagem F5A como na S7D. Assim, imagens SAR podem ser úteis na discriminação em áreas cultivadas por essas duas culturas na fase de máximo desenvolvimento. Para áreas de solo exposto, as imagens F5A e S7D apresentaram variações de tons de cinza, indicando serem inapropriadas para fins de discriminação e classificação digital.

O método de seleção das medidas e bandas de textura permitiu identificar o potencial de discriminação entre classes duas a duas e a geração das bandas de textura correspondentes às medidas de textura que melhor discriminam os alvos de interesse para as duas imagens utilizadas. Isto evitou a utilização de todas as medidas de textura e, conseqüentemente, redundância de informação e demanda computacional elevada. A utilização de filtros adaptativos de redução do ruído *speckle* melhorou a precisão das classificações digitais em relação às imagens originais, tanto para a imagem F5A como para a S7D.

Dentre os filtros testados, o filtro *Gamma*, janela 5 x 5 foi o mais eficiente para as duas imagens utilizadas. As classificações realizadas sobre as imagens de textura melhoraram, em geral, a precisão das classificações em relação às imagens F5A e S7D filtradas de *Gamma* 5 x 5, mostrando que as medidas texturais podem ser atributos úteis para maximizar a discriminação de alvos agrícolas. Para a imagem F5A, com exceção da classe solo exposto-1, as demais classes apresentaram melhor discriminação, mas com exatidão total e valor *kappa* inferiores à imagem F5A com filtro *Gamma* 5 x 5.

Para a imagem S7D, as classificações sobre as imagens de textura melhoraram a discriminação de todas as classes em relação à classificação da imagem S7D filtrada de *Gamma* 5 x 5. Entre-tanto, a exatidão total e o valor de *kappa* foram inferiores à imagem S7D filtrada *Gamma* 5 x 5, assim como na imagem F5A.

As classes água, área urbana, cana-de-açúcar-2, soja e solo exposto-1 apresentaram maior potencial de discriminação na imagem F5A quando submetida a filtros adaptativos e a atributos texturais (exatidão acima de 50%).

Já para a imagem S7D filtrada e medidas de textura derivadas, as classes com maior potencial de discriminação foram: água, área urbana, cana-de-açúcar-1, cana-de-açúcar-2, soja e solo exposto-1 (exatidão acima de 50%). Em geral, as classificações realizadas sobre as imagens de textura F5A apresentaram valores de discriminação ligeiramente melhores em relação às classificações realizadas sobre as imagens de textura derivadas da imagem S7D, possivelmente devido à perda da informação textural como resultado da resolução espacial inferior da imagem S7D em relação à imagem F5A.

## REFERÊNCIAS

- BRISCO, B. & BROWN, R.J. Agricultural applications with Radar. In: Henderson, F. M.; Lewis, A. J. **Principles and applications of imaging radar - manual of remote sensing**. (3ed). New York: John Wiley & Sons. p 381-406, 1997.
- BRISCO, B. & BROWN, R.J. Multidate SAR/TM synergism for crop classification in western Canada. **Photogrammetric Engineering and Remote Sensing**. v. 61, n. 8, p. 1009-1014, 1995.
- DOBSON, M. C. & ULABY, F. T. Microwave backscatter dependence on surface roughness, soil moisture and soil texture: Part III – Soil Tension. **IEEE Transactions on Geoscience and Remote Sensing**, v. GE-19, p. 51-61, 1981. 10.1109/TGRS.1981.350328
- DOBSON, M.C.; ULABY, F.T.; PIERCE, L.E. Land cover classification and estimation of terrain using Synthetic Aperture Radar. **Remote Sensing of Environment**, v. 51, n. 1, p. 199-214, 1995. [https://doi.org/10.1016/0034-4257\(94\)00075-X](https://doi.org/10.1016/0034-4257(94)00075-X)
- FOODY, G.M. On the compensation for change agreement in image classification accuracy assessment. **Photogrammetric Engineering and Remote Sensing**, v. 6, n. 10, p. 1459-1460, 1992.
- FORMAGGIO, A.R. & SANCHES, I.D. **Sensoriamento remoto em agricultura**. São Paulo: Oficina de Textos. 285 p. 2017.
- FORMAGGIO, A.R.; EPIPHANIO, J.C.N.; SIMÕES, M.S. Radar backscattering from an agricultural scene. **Pesquisa Agropecuária Brasileira**, v. 36, n. 5, p. 823-830, 2001.
- FRERY, A.C. **Algumas ferramentas estatísticas na síntese, processamento e análise de imagens de radar de abertura sintética**. São José dos Campos. 228 p. 1993. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais.
- FROST, V.S.; STILES, J.A.; SHANMUGAN, K.S.; HOLTZMAN, J.C. A model for radar images and its application to adaptive digital filtering of multiplicative noise. **IEEE Transactions on pattern analysis and machine intelligence**, v. 4, n. 2, p. 157-166, 1982. 10.1109/TPAMI.1982.4767223
- GREENSPAN, H.; GOODMAN, R.; CHELLAPPA, R.; ANDERSON, C.H. Learning texture discrimination rules in a multiresolution system. **IEEE Transactions on pattern analysis and machine intelligence**, v. 16, n. 9, p. 894-901, 1994. 10.1109/34.310685
- HARALICK, R.M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, v. 67, n. 5, p. 786-804, 1979. 10.1109/PROC.1979.11328
- HARALICK, R.M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. SMC-3, n. 6, p. 610-621, 1973. 10.1109/TSMC.1973.4309314
- HSU, S.Y. Texture-tone analysis for automated land-use mapping. **Photogrammetric Engineering and Remote Sensing**, v. 44, n. 11, p. 1393-1404, 1978.
- HUDSON, W.D. & RAMM, C.W. Correct formulation on the Kappa coefficient of agreement. **Photogrammetric Engineering and Remote Sensing**, v. 53, n. 4, p. 421-422, 1987.
- Instituto Nacional de Pesquisas Espaciais (INPE) – Divisão de Sensoriamento Remoto (INPE – DSR). **Cartas topográficas – ORB 222/76**. São José dos Campos. 1 CD-ROM, 2003.
- IPPOLITI-RAMILO, G.A.; EPIPHANIO, J.C.N.; SHIMABUKURO, Y.E.; FORMAGGIO, A.R. Sensoriamento remoto orbital como meio auxiliar na previsão de safras. **Agricultura em São Paulo**, v.46, n.1, p.89-101, 1999.
- IRONS, J.R. & PETERSEN, G.W. Texture transforms of remote sensing data. **Remote Sensing of Environment**, v. 11, n. 5, p. 359-370, 1981. [https://doi.org/10.1016/0034-4257\(81\)90033-X](https://doi.org/10.1016/0034-4257(81)90033-X)
- LANDIS, J.R.; & KOCH, G.G. The measurements of observer agreement for categorical data. **Biometrics**, v. 33, p. 159-174, 1977. <https://doi.org/10.2307/2529310>
- LEE, J. S. Digital image enhancement and noise filtering by use of local statistics. **IEEE Transactions on Pattern Analysis** **Machine Intelligence**, v. 2, n. 2, p. 165-171, 1980. 10.1109/TPAMI.1980.4766994
- LEWIS, A.J. & HENDERSON, F.M. Radar fundamentals: the geoscience perspective. In: Henderson, F. M.; Lewis, A. J. **Principles and applications of imaging radar – manual of remote sensing**. (3ed). New York: John Wiley & Sons, p. 131-181, 1997.
- LOPES, A.; NEZRY, E.; TOUZI, R.; LAUR, H. Structure detection and statistical adaptive speckle filtering in SAR images. **International Journal of Remote Sensing**, v. 14, n. 9, p. 1735-1758, 1993. <https://doi.org/10.1080/01431169308953999>
- LOPES, A.; TOUZI, R.; NEZRY, E. Adaptive speckle filters and scene heterogeneity. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 6, p. 992-1000, 1990. 10.1109/36.62623
- MATHER, P.M. **Computer processing of remotely-sensed images: an introduction**, 2 ed. Chichester: John Wiley & Sons, 292 p. 1999.
- MCNAIRN, H.; ELLIS, J.; VAN DER SANDEN, J.J.; HIROSE, T.; BROWN, R.J. Providing crop information using RADARSAT-1 and satellite optical imagery. **International Journal of Remote Sensing**, v. 23, n. 5, p. 851-870, 2002. <https://doi.org/10.1080/01431160110070753>
- MORAIS, M.C.; PARADELLA, W.R.; FREITAS, C.C. An assessment of the discrimination of Iron-mineralized laterites in the amazon region (Carajás province) based on textural attributes from C-band airborne SAR data. **Asian Journal of Geoinformatics**, v. 2, n. 3, p. 11-19, 2002.
- PRESUTTI, M.E.; FRANKLIN, S.E.; MOSKAL, L.M.; DICKSON, E.E. Supervised classification of multisource satellite image spectral and textural data for agricultural crop mapping in Buenos Aires Province, Argentina. **Canadian Journal of Remote Sensing**, v. 27, n. 6, p. 679-684, 2001. <https://doi.org/10.1080/07038992.2001.10854910>
- RADARSAT International. **RADARSAT Illuminated: your guide to products and services**. Richmond. Preliminary version 07195, 1995.
- RENNÓ, C.D. **Avaliação das medidas texturais na discriminação de classes de uso utilizando imagens SIR-C/X-SAR do perímetro irrigado de Bebedouro, Petrolina, PE**. São José dos Campos, 73 p. 1995. Dissertação (Mestrado em Sensoriamento remoto) – Instituto Nacional de Pesquisas Espaciais.
- RENNÓ, C.D. **Texture 1.0 - classificador por região**. São José dos Campos: INPE, 2003. Disp.em: <<http://www.dpi.inpe.br/~camilo>>. Acesso em: 9 de jun. de 2003.
- RICHARDS, J. A. **Remote sensing digital image analysis: an introduction**. Berlin: Springer-Verlag, 221 p. 1986.
- ROSENFELD, G.H. & FITZPATRICK-LINS, K. A coefficient of agreement as a measure of thematic classification accuracy. **Photogrammetric Engineering and Remote Sensing**. v. 52, n. 2, p. 223-227, 1986.
- SILVA JUNIOR, L.W.P. **Classificação da cobertura da terra na floresta nacional do Tapajós através de medidas de textura utilizando dados do radar ERS**. São José dos Campos, 164 p. 2002. Dissertação (Mestrado em Sensoriamento Remoto), Instituto Nacional de Pesquisas Espaciais.
- SMITH, A.M.; MAJOR, D.J.; MCNEIL, R.L.; WILLMS, W.D.; BRISCO, B.; BROWN, R.J. Complementarity radar and visible-infrared sensors in assessing rangeland condition. **Remote Sensing of Environment**. v. 52. p. 173-180, 1995. [https://doi.org/10.1016/0034-4257\(95\)00033-W](https://doi.org/10.1016/0034-4257(95)00033-W)
- SOARES, J.V.; RENNO, C.D.; FORMAGGIO, A.R.; YANASSE, C.C.F.; FRERY, A.C. An investigation of the selection of texture features for crop discrimination using SAR imagery. **Remote Sensing of Environment**, v. 59, n.2, p.234-247, 1997. [https://doi.org/10.1016/S0034-4257\(96\)00156-3](https://doi.org/10.1016/S0034-4257(96)00156-3)
- SOLER, L.S. **Deteção de manchas de óleo na superfície do mar por meio de técnicas de classificação textural de**

- imagens de radar de abertura sintética (RADARSAT-1).** São José dos Campos, 167 p. 2002. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais.
- TOUTIN, T. Map making with remote sensing data. In: NATO Advanced Research Workshop on Remote Sensing for Environmental Data in Albania: A strategy for integrated Management, Tirana. **Proceedings**. Albania, p. 65-87, 1999.
- TROPPIAIR, H. **Geossistemas e geossistemas paulistas**. Rio Claro: Universidade Estadual Paulista – UNESP, p. 71-74, 2000.
- ULABY, F.T.; KOUYATE, F.; BRISCO, B.; LEE WILLIAMS, T.H. Textural information in SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 24, n. 2, p. 235-245, 1986a. 10.1109/TGRS.1986.289643
- ULABY, F.T.; MOORE, R.K.; FUNG, A.K. **Microwave remote sensing: active and passive: radar remote sensing and surface scattering and emission theory**. 2 ed. Norwood, MA: Artech House, 1064 p. v. 2, 1982.
- ULABY, F.T.; MOORE, R.K.; FUNG, A.K. **Microwave remote sensing: active and passive: from theory to applications**. 2 ed. Norwood, MA. Artech House, 2162 p. v. 3, 1986b.
- UNSER, M. Sum and difference histograms for texture classification. **IEEE Transactions on Pattern Analysis and Machine Intelligence**. PAMI-8(1), p. 118-125, 1986. 10.1109/TPAMI.1986.4767760
- VAN DER SANDEN, J.J. **Radar remote sensing to support tropical forest management**. Georgetown, Guyana, 330 p. (Doctoral Dissertation) – Tropenbos-Guyana Programme, 1997.
- VIEIRA, P. R. **Desenvolvimento de classificadores de máxima verossimilhança pontuais e ICM para imagens de abertura sintética**. São José dos Campos, 227 p. 1996. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais.
- VIEIRA, P.R.; YANASSE, C.C.F.; FRERY, A.C.; SANT’ANNA, S. J. S. Um sistema de análise e classificação estatística para imagens SAR. In: Latin American Seminar on Radar Remote Sensing, 1., Buenos Aires, 2-4 Dec. 1997. **Image processing techniques**. Buenos Aires: ESA/INPE, p.179-185, 1997.
- WOOD, D.; MCNAIRN, H.; BROWN, R.J.; DIXON, R. The effect of dew on the use of RADARSAT-1 for crop monitoring: choosing between ascending and descending orbits. (Using RADARSAT-1 for crop monitoring: choosing between ascending and descending orbits). **Remote Sensing of Environment**. v. p. 241-247, 2002. [https://doi.org/10.1016/S0034-4257\(01\)00304-2](https://doi.org/10.1016/S0034-4257(01)00304-2).

*Submetido em 4 de setembro de 2023  
Aceito para publicação em 6 de março de 2024*